arXiv:0711.3691v2 [cs.CL] 27 Nov 2007

Outilex, plate-forme logicielle de traitement de textes écrits

Olivier Blanc, Matthieu Constant, Éric Laporte
IGM - Université de Marne-la-Vallée
5, bd Descartes - 77454 Marne-la-Vallée CEDEX 2
olivier.blanc@univ-mlv.fr, matthieu.constant@univ-mlv.fr,
eric.laporte@univ-mlv.fr

Résumé La plate-forme logicielle Outilex, qui sera mise à la disposition de la recherche, du développement et de l'industrie, comporte des composants logiciels qui effectuent toutes les opérations fondamentales du traitement automatique du texte écrit : traitements sans lexiques, exploitation de lexiques et de grammaires, gestion de ressources linguistiques. Les données manipulées sont structurées dans des formats XML, et également dans d'autres formats plus compacts, soit lisibles soit binaires, lorsque cela est nécessaire ; les convertisseurs de formats nécessaires sont inclus dans la plate-forme ; les formats de grammaires permettent de combiner des méthodes statistiques avec des méthodes fondées sur des ressources linguistiques. Enfin, des lexiques du français et de l'anglais issus du LADL, construits manuellement et d'une couverture substantielle seront distribuées avec la plate-forme sous licence LGPL-LR.

Abstract The Outilex software platform, which will be made available to research, development and industry, comprises software components implementing all the fundamental operations of written text processing : processing without lexicons, exploitation of lexicons and grammars, language resource management. All data are structured in XML formats, and also in more compact formats, either readable or binary, whenever necessary ; the required format converters are included in the platform ; the grammar formats allow for combining statistical approaches with resource-based approaches. Manually constructed lexicons for French and English, originating from the LADL, and of substantial coverage, will be distributed with the platform under LGPL-LR license.

Mots-clefs : Analyse syntaxique, motifs lexico-syntaxiques, analyse lexicale, ressources linguistiques, formats d'échange, automates finis, réseaux de transitions récursifs

Keywords: Syntactic parsing, lexico-syntactic patterns, lexical analysis, language resources, exchange formats, finite-state automata, recursive transition networks

1 Introduction

Le projet Outilex[1] vise à mettre à la disposition de la recherche, du développement et de l'industrie une plate-forme logicielle de traitement des langues naturelles ouverte et compatible avec l'utilisation d'XML, d'automates finis et de ressources linguistiques. En raison de son ambition internationale, Outilex a également participé aux efforts actuels de définition de normes en matière de modèles de ressources linguistiques. Nous présentons ses principaux résultats.

Les méthodes de traitement des langues naturelles sont encore aujourd'hui, la plupart du temps, mises en oeuvre par des logiciels dont la diffusion est limitée. De plus, on dispose rarement de formats d'échange ou de convertisseurs de formats qui permettraient de combiner plusieurs composants logiciels pour un même traitement. Quelques plates-formes font exception à cette situation générale, mais aucune n'est satisfaisante. Intex (Silberztein, 1993), FSM (Mohri *et al.*, 1998) et Xelda[2] sont fermés au développement collaboratif. Unitex (Paumier, 2003), inspiré d'Intex mais dont le code source est pour la quasi-totalité sous licence LGPL[3], ne fournit pas de formats XML. Les systèmes NLTK (Loper & Bird, 2002) et Gate (Cunningham, 2002) n'ont pas de fonctionnalités de gestion de ressources lexicales.

Le projet Outilex regroupe 10 partenaires français, dont 4 académiques et 6 industriels[4]. Il est coordonné par l'IGM et financé par le ministère de l'Industrie dans le cadre du Réseau national des technologies logicielles (RNTL). Préparé sous la direction de Maurice Gross, il a été lancé en 2002 et doit se terminer en 2006.

Les modules d'Outilex sont intégrés sous la forme d'une interface graphique programmée en Java qui appelle des programmes en C++. L'interface permet de travailler sur différents projets regroupant un ensemble de ressources (textes, dictionnaires et grammaires). L'utilisateur définit une chaîne de traitement. Les entrées, les sorties et les résultats intermédiaires sont visualisables dans un conteneur à onglets dédié à cet effet.

2 Traitement sans lexiques

Nous regroupons dans cette partie les opérations qui ne font pas appel à des informations extraites de ressources lexicales. Ces opérations ont pour résultat une représentation du texte comme séquence de tokens[5]. Le module qui les met en oeuvre prend en entrée un texte brut ou HTML et il produit en sortie le texte segmenté en paragraphes, en phrases et en tokens dans un format XML (seg.xml) proche de celui proposé par le projet de norme ISO d'annotation morpho-syntaxique de textes (MAF) (Clément & de la Clergerie, 2005) élaboré dans le cadre du projet RNIL[6]. Les éventuelles balises de mise en page HTML sont conservées et placées dans des éléments XML qui les distinguent des données textuelles. Les règles de segmentation en tokens et en phrases sont basées sur la catégorisation des caractères définie par la norme

[1]Ce travail a été en partie financé par le Ministère de l'Industrie et par le CNRS.

[2]http ://www.dcs.shef.ac.uk/ hamish/dalr/baslow/xelda.pdf.

[3]Lesser General Public License, http ://www.gnu.org/copyleft/lesser.html.

[4]Outre le développement de la plate-forme libre, placée pour l'essentiel sous la responsabilité des partenaires IGM et Systran, le projet comporte la réalisation de démonstrateurs propriétaires, dont nous ne parlerons pas ici.

[5]Nous n'avons pas inclus dans la plate-forme de traitements applicatifs opérant sur ce modèle de texte, ni sur le modèle encore plus simple du sac de tokens, mais de tels traitements nous semblent facile à interfacer, en raison justement de la simplicité des modèles sous-jacents.

[6]Ressources normalisées en ingénierie des langues.

<?xml version="1.0"?> <document original_format="txt"><par id="1"><tu id="s0"><token type="word" id="t1" alph="latin" case="capit">La</token> <token type="word" id="t2" alph="latin">police</token> <token type="word" id="t3" alph="latin">a</token> <token type="word" id="t4" alph="latin">saisi</token> <token type="numeric" id="t5">164</token> ... <token type="punctuation" id="t11">.</token></tu></par> </document>

FIG. 1 – Texte segmenté au format seg.xml

Unicode (ex. lettres, chiffres). À chaque token est associé un certain nombre d'informations telles que son type (mot, nombre, ponctuation, etc.), son alphabet (latin, grec), sa casse (mot en minuscule, commençant par une majuscule, etc.) ainsi que d'autres informations pour les autres symboles (signe de ponctuation ouvrant ou fermant, etc.). De plus, un identifiant est associé à chaque token qui sera conservé durant toutes les phases du traitement. Par exemple, la phrase *La police a saisi 164 procès-verbaux jeudi dernier* est segmentée comme dans la figure 1. Appliqué à un corpus de dépêches AFP (352 464 tokens), ce module traite 22 185 mots par seconde[7].

3 Traitement par lexiques

Les traitements évoqués dans la partie précédente ont pour résultat une représentation du texte comme séquence de tokens. Nous pensons qu'une plate-forme généraliste doit intégrer certaines notions fondamentales absentes de ce modèle, comme celle de mots composés ou expressions multi-mots, ou la séparation des emplois en cas d'ambiguïté. Les produits de la linguistique de corpus seuls (Schmid, 1994) ne sont pas de nature à résoudre les problèmes posés par de telles notions. L'un des moyens pour y parvenir est l'utilisation de lexiques et de grammaires. L'utilisation de lexiques par les entreprises du domaine s'est d'ailleurs largement étendue au cours des dernières années. C'est pourquoi Outilex fournit un jeu complet de composants logiciels pour les opérations sur les lexiques. De plus, dans le cadre de sa contribution à Outilex, l'IGM a rendu publique [8] une proportion substantielle des lexiques du LADL[9] pour le français (109 912 lemmes simples et 86 337 lemmes composés) [10] et l'anglais (166 150 lemmes simples et 13 361 lemmes composés). Ces ressources sont proposées sous la licence LGPL-LR[11], créée dans le cadre d'Outilex et agréée par la FSF[12]. Les programmes d'Outilex sont compatibles avec toutes les langues européennes à flexion par suffixes. Des extensions seront nécessaires pour les autres types de langues.

3.1 Formats de lexiques

L'absence de formats génériques et de documentation sur les données sont deux obstacles à l'utilisation et à l'échange de lexiques pour le traitement automatique des langues. Les formats

[7] Ce test et les tests suivants ont été effectués sur un ordinateur de bureau équipé d'un processeur Intel Pentium cadencé à 2.8 GHz et de 512 Mo de mémoire RAM.

[8] http ://infolingu.univ-mlv.fr, suivre Données linguistiques puis Dictionnaires.

[9] Laboratoire d'automatique documentaire et linguistique, Université Paris 7, 1968-2000.

[10] Le jeu d'étiquettes pour le français combine 13 catégories morpho-syntaxiques, 18 traits flexionnels et divers traits syntaxico-sémantiques.

[11] Lesser General Public License for Language Resources, http ://infolingu.univ-mlv.fr/lgpllr.html. Les droits et devoirs donnés aux utilisateurs par la licence LGPL-LR sont l'équivalent, pour les ressources linguistiques, de ceux donnés aux utilisateurs de la licence LGPL pour les logiciels.

[12] Free Software Foundation, http ://www.fsf.org/ .

adoptés par Outilex tirent parti de deux circonstances : d'une part, l'émergence actuelle de modèles de données consensuels dans les projets de normalisation ; d'autre part, le fait que l'IGM dispose de lexiques du français construits manuellement et d'une grande couverture[13]. Nous avons traduit en XML le format Dela et inséré dans les balises de la documentation sur les données. Le format obtenu pour les lexiques de formes fléchies, dic.xml, illustré par la fig. 2, est adapté à l'échange de données et compatible avec le modèle LMF (Francopoulo, 2003). Le format Dela, plus compact : *appelés du contingent,appelé du contingent.N+hum :mp*, est adapté à la visualisation sur écran et à la maintenance manuelle par les linguistes (Laporte, 2005). Nous avons donc réalisé des convertisseurs dans les deux sens entre ces deux formats. Il existe en outre un format opérationnel que nous décrirons dans la section 5.2.

```
<entry>
  <lemma>appelé du contingent</lemma>
  <pos name='noun'/>
  <feat name='subcat' value='human'/>
  <inflected>
    <form>appelés du contingent</form>
    <feat name='gender' value='masculine'/>
    <feat name='number' value='plural'/>
  </inflected>
</entry>
```

FIG. 2 – Un extrait de lexique au format dic.xml

```
<attrtype name='antepos' type='bool'>
  <true alias='g'/>
</attrtype>
<pos name='adj' cutename='A'>
  <attribute name='postpos' type='postpos' default='false' shortcut='yes'/>
  <attribute name='antepos' type='antepos' default='false' shortcut='yes'/>
  <attribute name='gender' type='gender' shortcut='yes'/>
  <attribute name='number' type='number' shortcut='yes'/>
</pos>
```

FIG. 3 – Extrait de la description d'un jeu d'étiquettes au format LingDef pour le français

En pratique, l'utilisation de lexiques permet de manipuler des jeux d'étiquettes complexes et d'une granularité fine, qui nécessitent une description formelle telle que celle de la fig. 3.

3.2 Consultation des lexiques

Notre étiqueteur morpho-syntaxique[14] prend un texte segmenté au format *seg.xml* en entrée et attribue à chaque forme (simple ou composée) l'ensemble des étiquettes lui correspondant extraites des lexiques indexés (cf. 5.2). Il est possible d'appliquer un ensemble de lexiques à un texte dans la même passe de traitement. De plus, un système de priorités permet de bloquer des analyses issues de lexiques à faible priorité si la forme considérée est également présente dans un lexique de priorité supérieure. Ainsi, nous fournissons par défaut un lexique général proposant un grand nombre d'analyses pour la langue standard, que l'utilisateur peut, pour une application spécifique, enrichir à l'aide de lexiques complémentaires et/ou filtrer avec un lexique prioritaire. Enfin, plusieurs options, qui peuvent se combiner entre elles, permettent de paramétrer la méthode de consultation : il est possible d'ignorer complètement la casse, ou les accents et autres signes diacritiques. Ces paramètres permettent d'adapter notre étiqueteur au texte analysé (article de journal, page internet, e-mail, etc.). Appliqué au corpus de dépêches AFP (cf. 2) avec les dictionnaires décrits en 3, Outilex étiquette une moyenne de 6 650 mots par seconde[15].

[13]Ces deux circonstances sont liées à des travaux effectués au LADL sous la direction de Maurice Gross, la première par l'intermédiaire du projet Genelex de normalisation de lexiques (Normier & Nossin, 1990), la deuxième à travers le système de lexiques Dela (Courtois, 1990), (Courtois, 2004).

[14]Les modules de la chaîne de traitement ayant été implémentés de manière à être indépendants les uns des autres, il est possible de substituer un autre étiqueteur à celui proposé par défaut.

[15]4,7 % des occurrences de tokens n'ont pas été trouvées dans le dictionnaire ; cette valeur tombe à 0,4 % si on déduit le nombre de celles qui commencent par une majuscule.

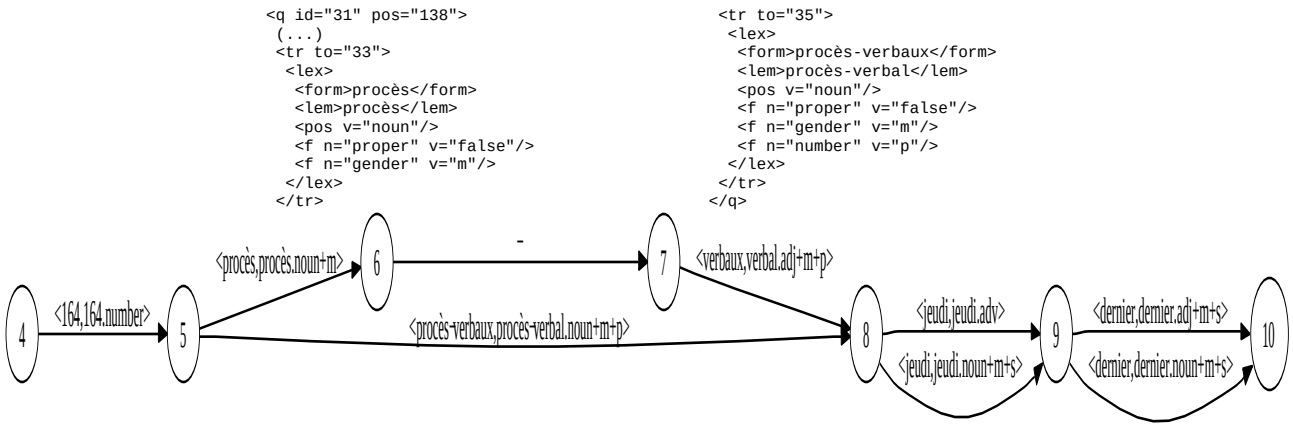

FIG. 4 – Extrait d'un automate acyclique représentant un texte étiqueté

3.3 Représentation du texte étiqueté

L'utilisation exclusive de lexiques pour étiqueter les textes produit des ambiguïtés lexicales. Le modèle le plus adapté pour représenter le texte étiqueté dans ces conditions est l'automate fini acyclique, en général appelé "treillis" dans ce contexte. La figure 4 présente une partie de l'automate du texte obtenu après l'étiquetage de la phrase segmentée présentée dans la section 2. Ce modèle prend en compte la notion de mot, distincte de la notion de token en raison notamment des expressions multi-mots.

La plate-forme Outilex a mis au point deux formats nouveaux pour la représentation du texte étiqueté. Le premier est le format binaire de sortie de l'outil de consultation des lexiques (3.2). Il permet un traitement rapide de textes de grande taille. Le deuxième, fsa.xml, est destiné à l'échange de données (fig. 4). C'est une traduction en XML du format fst2 d'Unitex. Le projet MAF propose un format voisin. Des fonctionnalités d'import/export entre ces deux formats sont prévues. Un convertisseur entre le format binaire et le format fsa.xml est disponible. De plus, les deux formats peuvent être exportés vers le format dot (Gansner & North, 2000).

4 Traitement par grammaires

Lors de l'étiquetage de mots par lexique, les étiquettes sont assignées aux mots d'une façon indépendante du contexte. Cette procédure est généralement complétée d'une façon ou d'une autre, dans les applications, par la prise en compte de contraintes sur des séquences de mots, et donc de "grammaires", au sens de ressources linguistiques spécifiant formellement de telles contraintes. Les formalismes grammaticaux étant la tour de Babel du traitement des langues naturelles, la plate-forme Outilex mise sur un formalisme minimal, qu'on peut résumer en trois points :

– pour la représentation des mots et des paradigmes de mots, la notion de masque lexical (Blanc & Dister, 2004), spécification d'un ensemble de mots par un ensemble de traits ;
– pour la représentation des contraintes sur les séquences, la notion de réseau de transitions récursif (RTN), outil purement formel, dépourvu de toute notion linguistique, au même titre que les transducteurs finis ou les grammaires algébriques ;
– les automates constituant les RTN peuvent être des transducteurs, c'est-à-dire comporter des

sorties, utiles par exemple pour insérer des balises dans les textes et formaliser ainsi des relations entre les segments identifiés.

Ces points permettent de construire des grammaires locales au sens de (Gross, 1993), (Gross, 1997).
Ce formalisme est utilisé dans des situations variées : extraction d'informations (Poibeau, 2001),(Nakamura, 2005) reconnaissance d'entités nommées (Krstev *et al.*, 2005), identification de structures grammaticales (Mason, 2004), (Danlos, 2005)... avec pour chacune de ces applications des taux de rappel et de précision qui égalent l'état de l'art du domaine. Nous avons ajouté la possibilité de pondérer les transitions, afin de permettre la réalisation de systèmes hybrides utilisant à la fois des méthodes statistiques et des méthodes fondées sur des ressources linguistiques. Nous appelons le formalisme obtenu réseau de transitions récursif pondérées (WRTN). Dans la fig. 5, par

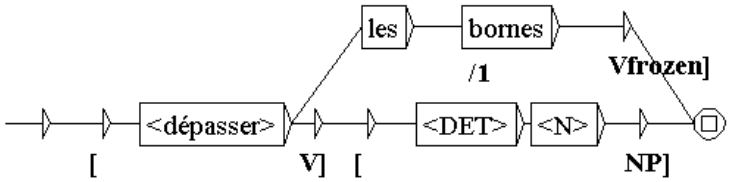

FIG. 5 – Exemple de WRTN

exemple, le chemin de poids 1, qui correspond à l'analyse avec expression figée, est prioritaire par rapport à l'autre (de poids 0 par défaut) correspondant à l'analyse compositionnelle.

4.1 Opérations sur les grammaires

Les WRTN sont construits sous la forme de graphes à l'aide d'un éditeur et sont sauvegardés dans un format XML appelé xgrf, élaboré à partir de (Sastre, 2005). Ces grammaires sont ensuite compilées dans un format XML appelé wrtn, plus adéquat aux traitements informatiques. Au cours de cette opération, chaque graphe est optimisé par les opérations d'émondation, suppression des transitions vides, déterminisation et minimisation. Il est également possible de transformer une grammaire en un transducteur fini équivalent, en faisant remonter les sous-graphes dans le graphe principal, éventuellement à une approximation près. Le résultat occupe plus d'espace mémoire mais accélère les traitements. Outilex offre la possibilité de transcoder les graphes du format grf (Unitex) au format xgrf (et inversement) et de les exporter vers le format dot (Gansner & North, 2000).

4.2 Traitements utilisant des grammaires

Les traitements utilisant des grammaires identifient dans le texte étiqueté les occurrences des motifs représentés dans les grammaires et peuvent produire plusieurs types de résultat :
– une concordance,
– une modification du texte linéaire ou de l'automate du texte,
– ou une forêt d'arbres d'analyse.

Tous ces traitements reposent sur un même moteur d'analyse, utilisant l'algorithme d'Earley (Earley, 1970) adapté pour traiter d'une part des WRTN (au lieu de grammaires algébriques) et d'autre part un texte sous forme d'automate acyclique (au lieu d'une séquence de mots). Notre analyseur fournit comme résultat une forêt partagée d'arbres d'analyse pondérés pour chaque

phrase analysée, les noeuds des arbres étant décorés par les éventuelles sorties présentes dans la grammaire. Appliqué au corpus de dépêches AFP avec une grammaire des groupes nominaux inspirée de (Paumier, 2003), il a traité 12 466 mots par seconde et trouvé 39 468 occurrences.

4.2.1 Présentation de concordances

Nous avons développé un concordancier qui permet de lister dans leur contexte d'apparition les différentes occurrences des motifs décrits par la grammaire. La taille des contextes gauche et droit peut être paramétrée par l'utilisateur. Les concordances peuvent être classées soit suivant leur ordre d'apparition dans le texte, soit par ordre lexicographique.

4.2.2 Application d'un transducteur au texte

Nous avons également développé une fonctionnalité d'application d'un transducteur sur le texte produisant un texte brut comportant les sorties spécifiées dans la grammaire[16]. Dans le cas de grammaires pondérées, les poids fournissent un critère de filtrage entre plusieurs analyses concurrentes. L'analyse retenue est celle dont le chemin a le poids le plus élevé. Un critère supplémentaire sur la longueur des séquences reconnues peut également être utilisé.

Pour des traitements plus complexes, une variante de cette fonctionnalité produit en sortie un automate correspondant à l'automate du texte auquel sont rajoutées de nouvelles transitions étiquetées par les sorties de la grammaire. Ce procédé, facilement itérable, permet de reconnaitre des segments de plus en plus grands. Il peut également être utilisé comme complément à l'étiquetage morpho-syntaxique pour la reconnaissance d'unités lexicales semi-figées dont les variations sont trop complexes pour être énumérées sous forme de liste mais qui peuvent être décrites dans des grammaires locales. Par exemple, la figure 6 présente l'automate de la phrase précédente après l'application de la grammaire des adverbes de temps de M. Gross.

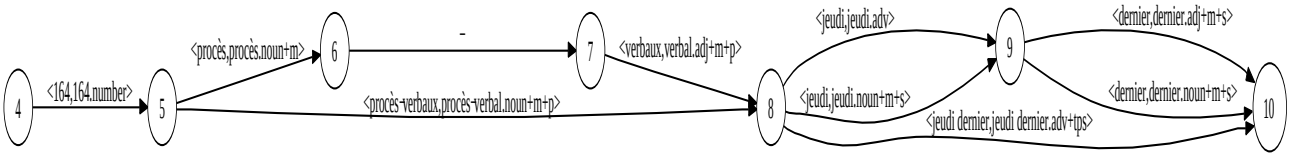

FIG. 6 – Résultat de l'application d'un transducteur sur l'automate du texte

4.2.3 Grammaire d'unification pour l'analyse syntaxique

Nous proposons enfin un module d'analyse syntaxique plus "fine" basé sur des grammaires d'unification dans le formalisme des WRTN décorés (Blanc & Constant, 2005). Ce formalisme allie au WRTN des équations fonctionnelles sur les traits permettant ainsi de formaliser des phénomènes syntaxique d'extraction ou de coréférence. Le résultat de notre analyseur consiste en une forêt partagée d'arbres syntaxiques ; à chaque arbre est associée une structure de traits dans laquelle sont représentées les relations grammaticales entre les constituants syntaxiques

[16]Les sorties peuvent au choix être insérées dans le texte d'origine ou remplacer les segments reconnus.

qui ont été identifiés durant l'analyse. La présentation de cet analyseur dépasse le cadre de cet article.

5 Gestion de ressources linguistiques

La réutilisation de lexiques présuppose une certaine flexibilité[17]. La gestion des lexiques et grammaires, dont l'IGM et Systran sont spécialistes, repose sur deux points : construction et maintenance manuelles des ressources dans un format lisible, sous la forme de petites unités cumulables (entrées lexicales, par exemple) ; compilation en un format directement opérationnel. Cependant, les manuels de traitement des langues naturelles, même généralistes et réputés, comme (Jurafsky & Martin, 2000), ne traitent pas ces techniques, qui nécessitent une collaboration étroite d'informaticiens et de linguistes ; et peu de systèmes fournissent les fonctionnalités requises (Xelda, Intex, Unitex). La plate-forme Outilex propose donc un jeu complet d'outils de gestion de ressources linguistiques.

5.1 Flexion automatique des lexiques

Le module de flexion automatique prend en entrée un lexique de lemmes et des règles de flexion et produit en sortie un lexique fléchi. Par exemple, le verbe *carry* appartient à la classe de flexion de la fig. 7 et le module produit entre autres la forme fléchie *carries* avec le code "prs_3s" (troisième personne du singulier au présent).

```
<Paradigm code="4">
   <StemTrigger>y</StemTrigger>
   <Inflection caseId="inf"><Form>y</Form></Inflection>
   <Inflection caseId="prs_1s"><Form>y</Form></Inflection>
   <Inflection caseId="prs_2s"><Form>y</Form></Inflection>
   <Inflection caseId="prs_3s"><Form>ies</Form></Inflection>
   <Inflection caseId="prs_p"><Form>y</Form></Inflection>
   <Inflection caseId="prt"><Form>ied</Form></Inflection>
   <Inflection caseId="imp"><Form>y</Form></Inflection>
   <Inflection caseId="ppt"><Form>ied</Form></Inflection>
   <Inflection caseId="ppr"><Form>ying</Form></Inflection>
</Paradigm>
```

FIG. 7 – Règle de flexion

5.2 Indexation des lexiques

Afin d'accélérer leur consultation (cf. 3.2), les lexiques sont indexés sur les formes fléchies en utilisant une représentation par automate fini minimal (Revuz, 1991) qui permet de les comprimer tout en offrant un accès rapide à l'information. Le format binaire obtenu (fichier .idx) est adapté aux lexiques à jeu d'étiquettes riche. Le tableau suivant décrit l'indexation du DELAF français (Courtois, 1990) et la taille du fichier obtenu après l'indexation du même lexique par les outils équivalents délivrés avec Unitex[18].

# formes fléchies	# formes canoniques	taille DELA (utf8)	taille XML (xml.gz)	taille idx	temps d'indexation	taille Unitex
1264170	122035	35 Mo	220 Mo (5.3 Mo)	9.5 Mo	1m03s	59 Mo

[17] Un lexique n'est pas une ressource statique. En raison de l'évolution de la langue, et en particulier de la langue technique, des mises à jour régulières sont nécessaires ; une nouvelle application d'un lexique peut mettre en jeu la sélection d'un vocabulaire spécifique au domaine. Il en est de même des grammaires, pour peu qu'elles soient lexicalisées.

[18] Les temps de calcul ne sont pas indiqués ici. Le programme d'Unitex étant trop demandeur en ressources mémoire, nous avons dû lancer l'opération sur une autre machine.

6 Conclusion et perspectives

La plate-forme Outilex, dans sa version préliminaire actuelle, effectue toutes les opérations fondamentales du traitement automatique du texte écrit : traitements sans lexiques, exploitation de lexiques et de grammaires, gestion de ressources linguistiques. Les données manipulées sont structurées dans des formats XML, et également dans d'autres formats plus compacts, soit lisibles soit binaires ; les convertisseurs de formats nécessaires sont inclus dans la plate-forme ; le formalisme des WRTN permet de combiner des méthodes statistiques avec des méthodes fondées sur des ressources linguistiques. Enfin, des lexiques issus du LADL, construits manuellement et d'une couverture substantielle seront distribuées avec la plate-forme sous licence LGPL-LR.

Le développement de la plate-forme a nécessité une expertise conjointe des éléments informatiques et linguistiques du problème ; il a pris en compte les besoins de la recherche fondamentale et ceux des applications. Nous pensons qu'il n'aurait pas été possible sans un consortium aussi varié. Au-delà de la fin du projet, l'avenir de la plate-forme Outilex est conçu dans le cadre du développement collaboratif. Nous espérons que la plate-forme actuelle, déjà compatible avec de nombreuses langues, sera étendue à d'autres et enrichies en fonctionnalités nouvelles.

Références

BLANC O. & CONSTANT M. (2005). Lexicalization of grammars with parameterized graphs. In *Proc. of RANLP 2005*, p. 117–121, Borovets, Bulgarie : INCOMA Ltd.

BLANC O. & DISTER A. (2004). Automates lexicaux avec structure de traits. In *Actes de RECITAL*, p. 23–32.

CLÉMENT L. & DE LA CLERGERIE É. (2005). MAF : a morphosyntactic annotation framework. In *Proc. of the Language and Technology Conference, Poznan, Poland*, p. 90–94.

COURTOIS B. (1990). Un système de dictionnaires électroniques pour les mots simples du français. *Langue Française*, **87**, 11–22.

COURTOIS B. (2004). Dictionnaires électroniques DELAF anglais et français. In C. LECLÈRE, É. LAPORTE, M. PIOT & M. SILBERZTEIN, Eds., *Lexique, Syntaxe et Lexique-Grammaire/Syntax, Lexis and Lexicon-Grammar*, Lingvisticae Investigationes Supplementa, p. 113–123. Amsterdam/Philadelphie : Benjamins.

CUNNINGHAM H. (2002). GATE, a general architecture for text engineering. *Computers and the Humanities*, **36**, 223–254.

DANLOS L. (2005). Automatic recognition of French expletive pronoun occurrences. In *Companion Volume of the International Joint Conference on Natural Language Processing, Jeju, Korea*, p. 2013.

EARLEY J. (1970). An efficient context-free parsing algorithm. *Comm. ACM*, **13**(2), 94–102.

FRANCOPOULO G. (2003). *Proposition de norme des lexiques pour le traitement automatique du langage*. AFNOR. 21 p.

GANSNER E. R. & NORTH S. C. (2000). An open graph visualization system and its applications to software engineering. *Software — Practice and Experience*, **30**(11), 1203–1233.

GROSS M. (1993). Local grammars and their representation by finite automata. In M. HOEY, Ed., *Data, Description, Discourse, Papers on the English Language in honour of John McH Sinclair*, p. 26–38. London : Harper-Collins.

GROSS M. (1997). The construction of local grammars. In E. ROCHE & Y. SCHABÈS, Eds., *Finite-state language processing*, Language, Speech, and Communication Series, p. 329–354. Cambridge (Mass.) : MIT Press.

JURAFSKY D. & MARTIN J. (2000). *Speech and language processing*. Prentice Hall. 934 p.

KRSTEV C., VITAS D., MAUREL D. & TRAN M. (2005). Multilingual ontology of proper names. In *Proc. of the Language and Technology Conference, Poznan, Poland*, p. 116–119.

LAPORTE É. (2005). Lexicon management and standard formats. In *Proc. of the Language and Technology Conference, Poznan, Poland*, p. 318–322.

LOPER E. & BIRD S. (2002). NLTK : the natural language toolkit. In *Proc. of the ACL Workshop on Effective Tools and Methodologies for Teaching Natural Language Processing and Computational Linguistics, Philadelphia*.

MASON O. (2004). Automatic processing of local grammar patterns. In *Proc. of the 7th Annual CLUK (the UK special-interest group for computational linguistics) Research Colloquium*.

MOHRI M., PEREIRA F. & RILEY M. (1998). A rational design for a weighted finite-state transducer library. *Lecture Notes in Computer Science*, **1436**.

NAKAMURA T. (2005). Analysing texts in a specific domain with local grammars : The case of stock exchange market reports. In *Linguistic Informatics - State of the Art and the Future*, p. 76–98. Amsterdam/Philadelphia : Benjamins.

NORMIER B. & NOSSIN M. (1990). Genelex project : Eureka for linguistic engineering. In *Proc. of the International Workshop on Electronic Dictionaries, OISA, Kanagawa, Japan*, p. 63–70.

PAUMIER S. (2003). *De la reconnaissance de formes linguistiques à l'analyse syntaxique. Volume 2, Manuel d'Unitex*. PhD thesis, IGM, Université de Marne-la-Vallée.

POIBEAU T. (2001). Extraction d'information dans les bases de données textuelles en génomique au moyen de transducteurs à états finis. In D. MAUREL, Ed., *Actes de TALN 2001 (Traitement automatique des langues naturelles)*, p. 295–304, Tours : ATALA Université de Tours.

REVUZ D. (1991). *Dictionnaires et lexiques : méthodes et algorithmes*. PhD thesis, Université Paris 7.

SASTRE J. M. (2005). XML-based representation formats of local grammars for NLP. In *Proc. of the Language and Technology Conference, Poznan, Poland*, p. 314–317.

SCHMID H. (1994). Probabilistic part-of-speech tagging using decision trees. *Proceedings of the International Conference on New Methods in Language Processing*.

SILBERZTEIN M. (1993). *Dictionnaires électroniques et analyse automatique de textes. Le système INTEX*. Paris : Masson. 234 p.